

Simulating signal from electronic sensor in motor vehicle using virtual sensor in vehicle control device, based on neural network model

Patent number: DE10010681
Publication date: 2001-09-06
Inventor: THEUERKAUF HEINZ J (DE); WINSEL THOMAS (DE);
AYEB MOHAMED (DE); LICHTENTHAELER DIRK (DE)
Applicant: THEUERKAUF HEINZ J (DE); WINSEL THOMAS (DE);
AYEB MOHAMED (DE); LICHTENTHAELER DIRK (DE)
Classification:
- **International:** **B60T8/174; F02D41/14; B60T8/17; F02D41/14;** (IPC1-
7): B60R16/02; F02D41/00; G05B15/02
- **European:** B60T8/174; F02D41/14B8
Application number: DE20001010681 20000304
Priority number(s): DE20001010681 20000304

Report a data error here

Abstract of DE10010681

The simulation uses a calculation model in the vehicle control device. The model is based on neural networks or fuzzy systems, or a combination of these with physically excited expert systems. The neural network typically using multi-layer perceptron arrangements, local feedback, external feedback, recurrent networks, and/or combined networks

Data supplied from the **esp@cenet** database - Worldwide



⑮ **BUNDESREPUBLIK
DEUTSCHLAND**



**DEUTSCHES
PATENT- UND
MARKENAMT**

⑫ **Offenlegungsschrift**
⑩ **DE 100 10 681 A 1**

⑤① Int. Cl.⁷:
B 60 R 16/02
F 02 D 41/00
G 05 B 15/02

②① Aktenzeichen: 100 10 681.1
②② Anmeldetag: 4. 3. 2000
④③ Offenlegungstag: 6. 9. 2001

DE 100 10 681 A 1

⑦① **Anmelder:**
Theuerkauf, Heinz J., Prof. Dr.-Ing., 34329 Nieste,
DE; Winsel, Thomas, Dipl.-Ing., 37671 Hörter, DE;
Ayeb, Mohamed, Dr.-Ing., 34125 Kassel, DE;
Lichtenthäler, Dirk, Dipl.-Ing., 57290 Neunkirchen,
DE

⑦② **Erfinder:**
gleich Anmelder

⑤⑤ **Für die Beurteilung der Patentfähigkeit in Betracht
zu ziehende Druckschriften:**
DE 197 45 427 A1
DE 195 27 323 A1
DE 44 19 317 A1
DE 42 09 150 A1
US 55 39 638 A
EP 08 77 309 A1

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen

⑤④ **Virtueller Drehmomentsensor auf Basis neuronaler Netze (MD-VNS) zur Implementierung in
Kraftfahrzeugsteuergeräte**

DE 100 10 681 A 1

Beschreibung

Anwendungsgebiet

Die Erfindung betrifft ein Verfahren bzw. eine Vorrichtung zur Unterstützung oder Erweiterung vorhandener Prozeßregelungen, einschließlich Prozeßsteuerungen und Prozeßüberwachungen im Kraftfahrzeug. Bei diesen Prozessen handelt es sich u. a. um den Verbrennungsmotor, das Getriebe, das Fahrwerk, die Spurführung und das Bremssystem. Alle oben aufgeführten Prozeßregelungen basieren auf zumeist gemessenen Signalen der verschiedenen Sensoren im Kraftfahrzeug. Mit Hilfe dieser Erfindung kann ein vorhandener Sensor bzw. dessen Sensorsignal ersetzt oder ein nicht verfügbares Sensorsignal bereitgestellt werden. Die Bereitstellung bzw. Nachbildung dieses Sensorsignals erfolgt mit Hilfe eines Berechnungsmodells, basierend auf den verbleibenden, verfügbaren Sensorsignalen. Eine solche Vorrichtung entsprechend dem Oberbegriff des Anspruchs 1, nachfolgend als virtueller Sensor bezeichnet, kann u. a. in ein Kraftfahrzeugsteuergerät implementiert werden.

Als besonders vorteilhafte Anwendung sei hierbei die Nachbildung des Motordrehmomentes bzw. einer vergleichbaren Größe genannt. Während des normalen Fahrzeugbetriebes ist eine Messung des Motordrehmomentes nur bedingt möglich, da die hierfür notwendige Sensorik äußerst umfangreich ausfällt und somit z. Z. nicht ökonomisch sinnvoll realisierbar ist. Abhilfe schafft ein im Steuergerät implementiertes Drehmomentenmodell entsprechend den Merkmalen nach Anspruch 4 und 5.

Stand der Technik

In allen herkömmlichen bzw. in Serie befindlichen Steuergeräten wird bereits eine virtuelle Lastgröße berechnet. Ein Drehmomenten-Modell wurde jedoch erst in aktuelleren Steuergeräten implementiert. Beide Berechnungsmodelle basieren auf den Signalen der Sensoren für Motordrehzahl, Motordrehposition, Fahrpedalposition, Luftmassenfluß bzw. alternativ Saugrohrdruck, Lambda-Wert, Motortemperatur und den Ausgangssignalen des Steuergerätes für Zündung und Einspritzung. Die Berechnung erfolgt i. a. durch die Auswertung von im Speicher abgelegten Kennfeldern und wird z. T. durch Adaptionsverfahren ergänzt, womit u. a. Alterungs- und Witterungseinflüsse berücksichtigt werden.

Nachteile des Standes der Technik

Die bereits vorhandenen virtuellen Drehmomentsensoren bzw. -modelle weisen während transientser Zustände eine unbefriedigende Übereinstimmung mit dem realen Drehmomentverlauf des Motors auf. Diese Abweichungen treten insbesondere bei Lastwechsel auf, bedingt z. B. von Klimakompressoren oder mechanischen Ansaugluft-Ladevorrichtungen (u. a. Abgaslader, Kompressor).

Die Parametrierung der aktueller Drehmomentmodelle, d. h. die Applikation der Modelle an verschiedene Motorvarianten ist sehr aufwendig, benötigt ein großes Maß an Prozeßkenntnis und ist somit nur unzureichend automatisierbar.

Aufgabe der Erfindung

Mit dem Verfahren muß ein vorhandener Sensor bzw. dessen Sensorsignal so ersetzt oder ein nicht verfügbares Sensorsignal so bereitgestellt werden, daß der Unterschied zum real gemessenen Signal vernachlässigt werden kann. Die Erfindung, d. h. der virtuelle Drehmomentsensor bzw. das -modell, muß unter Verwendung der für herkömmliche Steuergeräte eingesetzten Sensorik in der Lage sein, für alle Betriebsbereiche des Motors dessen realen Drehmomentverlauf mit guter Übereinstimmung im Quasi-Stationären als auch während transientser Zustände nachzubilden. Hierbei muß das Verfahren hinsichtlich der benötigten Rechenleistung und des benötigten Speicherbedarfs für die Applikation auf herkömmlichen Steuergeräten ohne zusätzliche Hardware geeignet sein.

Die Applikation der Modelle an verschiedene Motorvarianten soll weitgehend automatisiert erfolgen.

Lösung der Aufgabe

Der virtuelle Sensor wird mittels eines Berechnungsmodells nach den Merkmalen der Ansprüche 1 bis 3, d. h. unter Verwendung neuronaler Netze aufgebaut.

Insbesondere wird der virtuelle Drehmomentsensor zur Implementierung in Kraftfahrzeugsteuergeräte (MD-VNS) nach den Merkmalen der Ansprüche 4 und 5 konzipiert.

Vorteile der Erfindung

Durch dieses Verfahren gemäß den Merkmalen der Ansprüche 1 bis 5, d. h. dem Einsatz Neuronaler Netze in der Modellstruktur der virtuellen Sensoren, können die oben aufgeführten Anforderungen erfüllt bzw. Verbesserungen erreicht werden:

Da Neuronale Netze sich bekanntermaßen ausgesprochen gut zur Nachbildung nichtlinearer Funktionen eignen, kann durch eine Modellstrukturierung nach den Ansprüchen 1 bis 3, einschließlich eines geeigneten Lernverfahrens, eine ausreichend hohe Übereinstimmung zwischen realem und virtuellem Sensor erreicht werden.

Durch Verwendung eines Lernverfahrens zur Optimierung der neuronalen Netzparameter kann der Applikationsvorgang weitgehend automatisch erfolgen.

Es ist zudem möglich, weitere Sensoren im Kraftfahrzeug mit Hilfe des vorgestellten Verfahrens zu ersetzen.

1. Einleitung

Ein virtueller Sensor zur Implementierung in Kraftfahrzeugsteuergeräten (ECU's) nach den Merkmalen der Ansprüche 1 bis 5 entspricht einem Berechnungsmodell, dessen Struktur neuronale Netze enthält. Dieses Berechnungsmodell wird in oder an einem Steuergerät untergebracht, wie in Abb. 1 skizziert. Es verwendet nur Ein-, Ausgangs und interne Signale, die auch in herkömmlichen Steuergeräten zugänglich sind.

Als Eingänge des Modells bzw. virtuellen Sensors werden

- a) die Signale der Sensoren, d. h. die Eingangssignale des Steuergerätes, für
 - Motordrehzahl n und -position ϕ_{KW} ,
 - Drosselklappenwinkel α_{DK} bzw. Fahrpedalposition α_{PW} ,
 - Luftmassenfluß m_{Luft} , bzw. alternativ Saugrohrdruck p_{Saug} ,
 - Restsauerstoff im Abgas (Lambda-Wert) λ ,
 - Motortemperatur ϑ_{Mot} ,
 - Luftdruck p_{Luft} und -temperatur ϑ_{Luft} ,
 - ggf. Aggregate zur Ansaugluftaufladung,
 - ggf. Klopfneigung p_{Klopf} ,
 - ggf. Abgasrückführung (AGR),
 - ggf. Tankentlüftung $m_{Tank, Rück}$,
- b) die Ausgangssignale des Steuergerätes für
 - Zündung $\alpha_{Zünd}$,
 - Einspritzung t_{Ein} ,
- c) und ggf. weitere, im Steuergerät verfügbare analoge oder digitale Informationen (u. a. CAN-Bus, MOST)

verwendet.

Ausgang des Modells ist das Signal des zu ersetzenden bzw. des bereitzustellenden Sensors. Im Fall des virtuellen Drehmomentsensors (MD-VNS) ist dieses ein Signal, welches dem Drehmoment an der Kurbelwelle entspricht.

In einem elektronischen Kraftfahrzeugsteuergerät sind, den Modelleingängen äquivalenten Werte als digitale Information abgelegt. Diese Abtastwerte werden mit neuronalen Strukturen, mittels Hardware und/oder Software verarbeitet, deren Struktur nachfolgend beschrieben wird.

2. Neuronale Modellstruktur

Zur Festlegung der neuronalen Modellstrukturen, die den Merkmalen der Ansprüche 1 bis 5 zugrunde liegen, werden diese nachfolgend näher spezifiziert. Derartige Strukturen werden häufig auch als Fuzzy-Modelle, Fuzzy-Neuro-Modelle o. ä. bezeichnet.

2.1 Neuronale Netze

Ein neuronales Netz besteht i. a. aus mehreren Neuronen, deren Ein- und Ausgänge miteinander verbunden sind. Ein einzelnes Neuron stellt hierbei eine einfache Einheit zur Verarbeitung von Informationen bzw. von Signalen dar. Die Eingänge des Neurons, d. h. der mehrdimensionale Eingangsraum wird in der Regel auf einen eindimensionalen Ausgangsraum projiziert, der durch eine Aktivierungsfunktion ausgegeben wird. Die massive parallele Verarbeitung von Eingabedaten durch die jeweils einfachen Neuronen erklärt die Leistungsfähigkeit der gesamten Netzstruktur. Neuronale Netze, die nur Ein- und Ausgangsverbindungen ohne Zeitverzögerung bzw. Speicherung der Zustände aufweisen, werden als statische neuronale Netze bezeichnet. Im Gegensatz dazu, beinhalten dynamische oder rekurrente Netzstrukturen mindestens einen Zustandsspeicher.

2.1.1 Statische neuronale Netze

Die Fähigkeit statischer neuronaler Netze zur Nachbildung nichtlinearer statischer Zusammenhänge, d. h. zur Approximation kontinuierlicher Funktionen mit einer begrenzten Anzahl von Unstetigkeiten, wurde in mehreren Studien bewiesen [Cybe1989] sowie [HoSt1989]. Diese Studien machen aber keine Aussagen zum Netzaufbau, d. h. hinsichtlich der optimalen Anzahl der Schichten oder zur Festlegung der optimalen Neuronenzahl in einzelnen Schichten, um konkrete Aufgabenstellungen optimal zu lösen. Weiterhin geben sie keine Antworten zur Art der Initialisierung, um bei vorhandener optimaler neuronaler Approximatorstruktur eine optimale Approximation für konkrete Aufgabenstellung zu erreichen. Diese Schwierigkeiten sind auf das Fehlen allgemeingültiger globaler Eigenschaften der eingesetzten Algorithmen zum Lösen nichtlinearer Gleichungssysteme zurückzuführen. Diese Algorithmen werden als Lernverfahren für neuronale Netze, d. h. zur Bestimmung der Netzparameter verwendet und beruhen in der Regel auf dem Gradienten-Verfahren und/oder dem Newton-Verfahren. Aussagen über diese Verfahren sind nur lokal möglich, so daß die iterative Suche bereits "ausreichend nah" an der gesuchten Lösung beginnen muß.

Zur Nachbildung nichtlinearer Zusammenhänge benötigt ein neuronales Netz zumindest einige Neuronen mit nichtlinearem Übertragungsverhalten, d. h. nichtlineare Aktivierungsfunktionen. Die verwendeten Aktivierungsfunktionen bestimmen weitgehend das Inter- und Extrapolationsverhalten des neuronalen Netzes. Das Interpolationsverhalten neuronaler Modelle ist bei Verwendung sogenannter Quetschfunktionen (z. B. sigmoidaler Funktionen als Aktivierungsfunktionen) i. a. besser als z. B. bei Verwendung von Polynom-Approximatoren. Das Extrapolationsverhalten von neuronalen Netzen ist i. a. unbestimmt. Die Verwendung von Quetschfunktionen in der Zwischenschicht von Neuro-Modellen stellt die Beschränktheit der Ausgänge für beliebige Eingänge sicher.

Als Beispiel für ein konventionelles statisches neuronales Netz sei hier das Multi-Layer-Perceptron (MLP) genannt und näher erläutert. Seine Struktur gewährleistet die Nachbildung statischer Kennfelder mit ausreichender Approximationsgüte.

Multi-Layer-Perceptron (MLP)

Das MLP besteht aus mehreren Neuronenschichten wie in Abb. 2 dargestellt. Die Struktur ist strikt vorwärts gerichtet und gehört zur Gruppe der Feed-Forward-Netze. Für die Anwendung als Teilmodell im virtuellen (Drehmoment) Sensor hat sich eine dreischichtige $(N_U | N | N_Y)$ -MLP-Struktur als ausreichend erwiesen. In der Eingangsschicht werden alle N_U Eingänge $u = [u_1, \dots, u_{N_U}]^T$ direkt zur verborgenen Schicht #2 durchgeführt und stehen dort jedem der N verdeckten Neuronen als Eingänge zur Verfügung. Im i -ten Neuron der k -ten Schicht ergibt sich als Ausgang

$$y_{(i,k)}^{(k)} = f_{(i)}^{(k)} \left(\sum_j w_{(i,j)}^{(k)} \cdot u_{(j)}^{(k)} + b_{(i,k)}^{(k)} \right)$$

wobei z. B. für $k = 2$, als Bereich der Laufvariable $j = 1, 2, \dots, N_U$ gilt. Die log-sigmoidale Aktivierungsfunktion

$$f_{(i)}^{(2)}(\xi) = \frac{1}{1 + e^{-\xi}}$$

wird in jedem Neuron der verdeckten Schicht #2 eingesetzt. In den N_Y Neuronen der Ausgangsschicht #3 werden die Ausgänge der Schicht #2 gewichtet aufsummiert und durch eine lineare Aktivierungsfunktion als Gesamtnetzausgänge $y = [y_1, \dots, y_{N_Y}]^T$ ausgegeben. In Abb. 2 ist eine (3|4|1)-MLP-Struktur dargestellt mit $N_U = 3$ Eingängen, mit $N = 4$ verdeckten Neuronen und mit $N_Y = 1$ Ausgang.

Die Gesamtheit aller Wichtungen $W_{(i,j)}^{(k)}$ und Bias $B_{(i,k)}^{(k)}$, zusammengefaßt in den Parameter- bzw. Wichtungsmatrizen

$$W^{(1)} := \left(w_{(i,j)}^{(2)} \right) \in \mathbb{R}^{N \times N_U} \quad B^{(1)} := \left(b_{(i,k)}^{(2)} \right) \in \mathbb{R}^{N \times 1}$$

und

$$W^{(2)} := \left(w_{(i,j)}^{(3)} \right) \in \mathbb{R}^{N_Y \times N} \quad B^{(2)} := \left(b_{(i,k)}^{(3)} \right) \in \mathbb{R}^{N_Y \times 1}$$

bestimmen das Verhalten der neuronalen MLP-Gesamtstruktur

$$y = B^{(2)} + W^{(2)} \cdot \left(1 + e^{-\left(B^{(1)} + W^{(1)} \cdot u \right)} \right)^{-1}$$

Lernverfahren

Während des Trainings bzw. des Lernens werden Parameter bzw. Wichtungen ermittelt, mit denen die quadratische Fehlerfunktion

$$e(W^{(1)}, B^{(1)}, W^{(2)}, B^{(2)}) = \frac{1}{2} (y_{\text{Soll}} - y)^T \cdot (y_{\text{Soll}} - y)$$

minimiert wird.

Zu Beginn eines Lernvorgangs kann die Initialisierung der Wichtungen der verdeckten Schicht, also der Neuronen mit einer log-sigmoidalen Aktivierungsfunktion nach Nguyen-Widrow (NgWi1990) durchgeführt werden. Die Wichtungen der Neuronen mit linearer Aktivierungsfunktion in der Ausgangsschicht können mittels symmetrischem Zufallsgenerator initialisiert werden. Das Anlernen des funktionalen Zusammenhangs zwischen Ein- und Ausgängen kann in effektiver Weise nach dem Levenberg-Marquardt-Verfahren [Marq1963] und [HaMe1994] erfolgen. Diese Methode ist eine Kombination der Gradienten-Methode und des Newton-Verfahrens und konvergiert schneller als das bekannte Back-Propagation Verfahren, benötigt aber eine höhere Speicherkapazität während der Trainingsphase.

2.1.2 Rekurrente neuronale Netze

Ein rekurrentes oder dynamisches neuronales Netz ist dadurch gekennzeichnet, daß seine Netzstruktur eine Zeitverzögerung oder Speicherung mindestens eines Zustandes, Ein- oder Ausgangswertes seiner Neuronen vorsieht.

Ausgehend von einer allgemeinen rekurrenten Struktur, in der alle Neuronen vollständig miteinander verbunden sein können und an jeder Verbindung ein Speicherelement enthalten sein kann, haben sich einige spezielle Strukturen herausgebildet. Die Spezialisierung erfolgt durch Einschränkung der Vielfalt zulässiger Verbindungen und bzgl. der Speicherplatzierungen. Trotz hierdurch bedingter, prinzipieller Einschränkung der Approximationsfähigkeit haben sich diese speziellen Strukturen als äußerst vorteilhaft herausgestellt, besonders hinsichtlich der Kriterien:

– Kompaktheit und Zeitbedarf der Lernverfahren,

- Unabhängigkeit von der Initialisierung,
- ausreichende Approximationsgüte,
- Robustheit gegenüber Parameter- oder Eingangsvariationen (Rauschen),
- Nachweismöglichkeiten für stabiles dynamisches Modellverhalten,
- Inter- und Extrapolationsverhalten.

Die nachfolgend beschriebenen Strukturen wurden bereits im Rahmen der Forschungsarbeiten zur "Simulation technischer Systeme" vorteilhaft eingesetzt (vgl. u. a. [SAE1998]). So werden im Zusammenhang mit einem öffentlich geförderten Projekt, neben allgemeinen Systemuntersuchungen auf dem Gebiet dynamischer neuronaler Netze, intelligente Verfahren zur automatisierten Modellgenerierung am Beispiel von Verbrennungsmotoren entwickelt. Ziel des Vorhabens ist die Gewinnung echtzeitfähiger, aus physikalischen und neuronalen Modellansätzen kombinierter Motorenmodelle.

Struktur mit lokaler Rückführung

Lokale Rückführungen mit Zustandsspeicherung erweitern ein statisches zu einem dynamischen Netz. Hierbei wird weder über mehrere Neuronenschichten zurückgeführt noch bestehen zeitverzögerte Verbindungen zwischen den Neuronen innerhalb einer Schicht. Sondern in bestimmten Schichten besitzt jedes Neuron eine individuelle Rückführung, verfügt somit über eine eingebaute Dynamik, wie in Abb. 3 dargestellt. Hierbei handelt es sich um sogenannte Local-Recurrent-Global-Feedforward (LRGF) Netze.

Diese Struktur ermöglicht eine Überprüfung des dynamischen Modellverhaltens hinsichtlich Stabilität mit Hilfe des Kriteriums:

Ein neuronales LRGF-Netz (vgl. Abb. 3) ist global asymptotisch stabil, wenn die Verstärkungsfaktoren aller lokalen Rückführungen vom Betrag kleiner 1 sind.

Dieses Stabilitätskriterium läßt sich somit in ein Lernverfahren integrieren, indem sichergestellt wird, daß alle Parameter bzw. Wichtungen in den lokalen Rückführungen vom Betrag stets kleiner 1 sind.

Da die internen Zustände des Netzwerkes i. a. nicht verfügbar sind, muß das Lernverfahren in der Ausgangsfehler- bzw. in der parallelen Modellkonfiguration durchgeführt werden, z. B. mit Backpropagation-Through-Time, wodurch sich der Lernprozeß häufig sehr zeitaufwendig gestaltet.

Struktur mit externer Rückführung

Eine weitere Möglichkeit zur Erweiterung eines statischen zu einem dynamischen Netz ergibt sich, wenn dem statischen neuronalen Approximator zeitlich verzögerte Ein- und Ausgänge des Prozesses bzw. des Modells zugeführt werden. Eine solche Struktur wird als Time-Delay-Neural-Network (TDNN) bezeichnet und verfügt über eine externe Dynamik, wie in Abb. 4 dargestellt.

Die Überprüfung bzw. ein Nachweis der Stabilität dieses dynamischen Simulationsmodells gestaltet sich i. a. relativ aufwendig. Die Verwendung eines MLP wie in Abb. 2 als statischer Approximationskern, ermöglicht die Formulierung eines einfach anwendbaren Stabilitätskriteriums, welches sich ebenfalls in ein Lernverfahren integrieren läßt.

Ein TDNN (vgl. Abb. 4) mit einem statischen (2nIN1)-MLP Approximationskern (vgl. Abb. 2) ist global asymptotisch stabil, wenn

$$\left(\sum_{i=1}^N \sum_{j=1}^n (w_{i,j}^{(1)})^2 \right) \left(\sum_{v=1}^N (w_{1,v}^{(2)})^2 \right) < \frac{(n-1)^{n-1}}{n^n}$$

Hierbei wurde als Eingang des MLP ein Vektor

$$[Y(k-1), \dots, y(k-n), u_1(k-1), \dots, u_1(k-n), u_m(k-1), \dots, u_m(k-n)]^T$$

vorausgesetzt.

Da die TDNN-Struktur im statischen Approximationskern keine internen dynamischen Zustände aufweist, kann ein Lernverfahren sowohl in der Ausgangsfehler- bzw. in der parallelen Modellkonfiguration als auch in der Gleichungsfehler- bzw. in der seriellparallelen Modellkonfiguration durchgeführt werden. Im letzteren Fall wird zunächst ein Prädiktionsmodell trainiert, was i. a. mit einem erheblichen Zeitgewinn gegenüber der parallelen Modellkonfiguration verbunden ist. Erfolgt die Optimierung des statischen Approximationskerns unter Berücksichtigung hinreichender Approximationsgüte, Robustheit sowie Inter- und Extrapolationsfähigkeit, so ist in der Regel eine gute Simulationsfähigkeit des TDNN-Modells gegeben.

2.2 Kombinierte neuronale Netze

Eine Verwendung rein neuronaler Strukturen, wie im vorhergehenden Kapitel beschrieben, im sogenannten Black-Box-Modellverfahren führt u. U. bei der Anwendung virtueller Sensor zu nicht optimalen Ergebnissen. Die Einbindung vorhandener Kenntnisse des nachzubildenden Prozesses, in Form physikalischer Gleichungen ist hierbei vorteilhaft. Die Vorteile beider Modellgenerierungsverfahren können kombiniert werden.

Physikalisch motivierte Grundstruktur zur Aufteilung in neuronale Teilmodelle

In der Abb. 5 ist eine vereinfachte Darstellung der physikalischen Struktur eines Otto-Verbrennungsmotors gezeigt,

mit der eine Nachbildung des Drehmomentes an der Kurbelwelle durchgeführt werden kann. Basierend auf den Eingängen Motordrehzahl n , Fahrpedalposition α_{DK} , Kraftstoff-Einspritzzeit t_{Ein} und Zündwinkel $\alpha_{Zünd}$ kann mit diesem Modell u. a. ein virtueller Drehmoment-Sensor aufgebaut werden.

Im Gegensatz zu einem in sich geschlossenen Black-Box-Modell $M_{Dreh} = f_{TDNN}(n, \alpha_{DK}, t_{Ein}, \alpha_{Zünd}, \dots)$ wird lediglich das physikalische Saugrohrdruck-Teilmodell durch ein dynamisches neuronales Netz $p_{Saug} = f_{TDNN}(n, \alpha_{DK})$ ersetzt. In analoger Vorgehensweise werden die restlichen Teilmodelle für den Kraftstoffpfad, die Gemischbildung und den eigentlichen Verbrennungsprozeß durch rekurrente neuronale Netze ersetzt.

Besonderes Augenmerk ist zu richten auf Teilprozesse, die bereits mit statischen Netzstrukturen ausreichend nachzubilden sind. Durch diese Maßnahme kann das Modell hinsichtlich Handhabbarkeit, Übersichtlichkeit und Robustheit deutlich verbessert werden.

3. Literatur

- [Cybe1989] Cybenko, G., "Approximation by Superpositions of a sigmoidal function", Math. Control, Sig. Syst., 2, 1989, pp 303-314.
- [HaMe1994] M. T. Hagan, M. B. Menhaj, "Training Feedforward Networks with the Marquardt Algorithm", IEEE Transactions on Neural Networks, Vol 5, Nr 6, pp 989-993, November 1994.
- [HoSt1989] Hornik K., Stinchcombe M., White H., "Multilayer feedforward networks are universal approximators", Neural Networks, 2, 1989, pp 359-366.
- [Marq1963] D. Marquardt, "An Algorithm for least squares estimation of non-linear Parameters", J. Soc. Ind. Appl. Math, pp 431-441, 1963.
- [NgWi1990] D. Nguyen, B. Widrow, "Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptive Weights", International Joint Conference of Neural Networks, vol 3, pp 21-26, July 1990.
- [SAE1998] M. Ayebe, D. Lichtenthäler, H. J. Theuerkauf, T. Winsel; "SI Engine Modeling Using Neural Networks", SAE International Congress, Detroit - Michigan USA, 1998.

Patentansprüche

1. Nachbildung des Signalverlaufs eines elektronischen Sensors im Kraftfahrzeug mittels virtuellem Sensor in einem elektronischen Fahrzeugsteuergerät bzw. -regelgerät, **dadurch gekennzeichnet**, daß die Nachbildung mit einem Berechnungsmodell im Fahrzeugsteuergerät erfolgt, das auf Neuronalen Netzen basiert.
2. Verfahren und Einrichtung nach Anspruch 1, dadurch gekennzeichnet, daß die Nachbildung mit einem Berechnungsmodell im Fahrzeugsteuergerät erfolgt, das auf Fuzzy-Systemen basiert.
3. Verfahren und Einrichtung nach Anspruch 1 oder 2, dadurch gekennzeichnet, daß die Nachbildung mit einem Berechnungsmodell im Fahrzeugsteuergerät erfolgt, das auf einer Kombination aus Neuronalen Netzen, Fuzzy-Systemen und physikalisch motivierten Expertensystemen basiert.
4. Verfahren und Einrichtung nach einem der vorhergehenden Ansprüche, dadurch gekennzeichnet, daß die Nachbildung des Signalverlaufs eines Drehmomentensensors im Kraftfahrzeug mittels virtuellem Drehmomentensensor erfolgt.
5. Verfahren und Einrichtung nach einem der vorhergehenden Ansprüche, dadurch gekennzeichnet, daß die Nachbildung das Motordrehmoment oder einer vergleichbaren Größe im Kraftfahrzeug mittels virtuellem Drehmomentensensor erfolgt.

Hierzu 3 Seite(n) Zeichnungen

- Leerseite -

Abbildungen zum Kapitel „Beschreibung der Patentanmeldung“ [B]

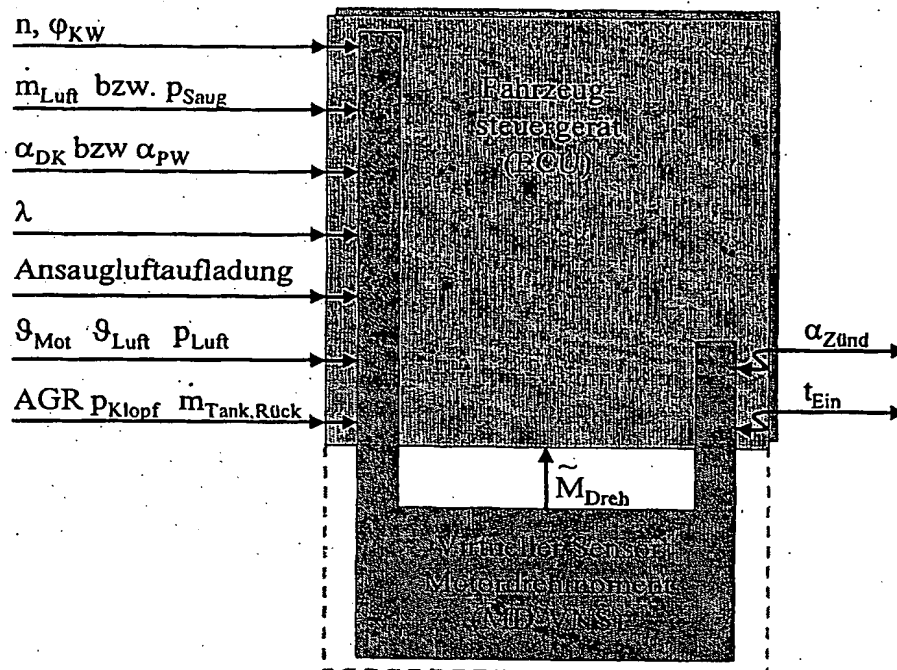


Abb. 1: Virtueller Sensor auf Basis neuronaler Netze (VNS) zur Implementierung in Kraftfahrzeugsteuergeräten (hier Virtueller Drehmoment-Sensor MD-VNS)




Abb. 2: Dreischichtiges Multi-Layer-Perceptron, hier (3|4|1)-MLP, zur Nachbildung statischer, nichtlinearer Funktionszusammenhänge

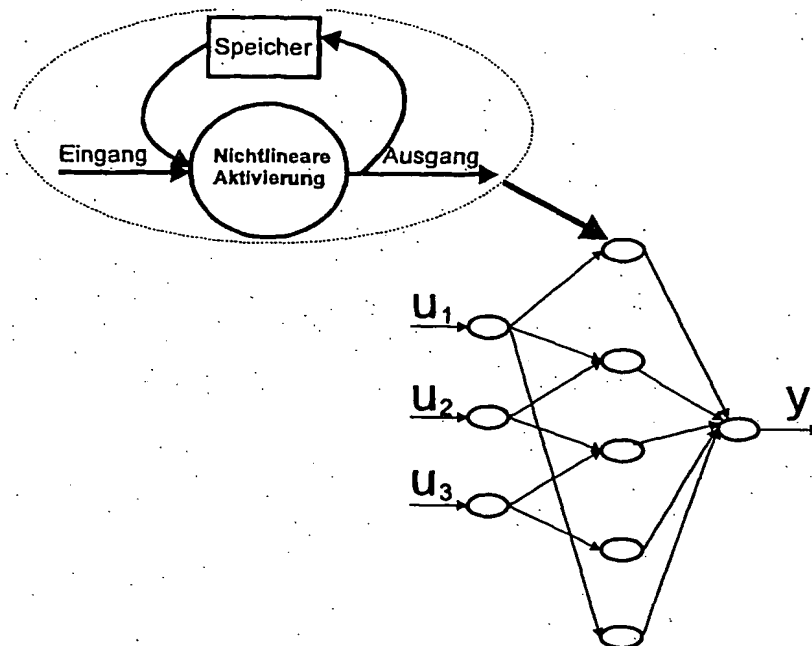


Abb. 3: Dynamisches neuronales Netz mit der speziellen Struktur: Local-Recurrent-Global-Feedforward Netzwerk




Abb. 4: Dynamisches neuronales Netz mit der speziellen Struktur: Time-Delay-Neural-Network

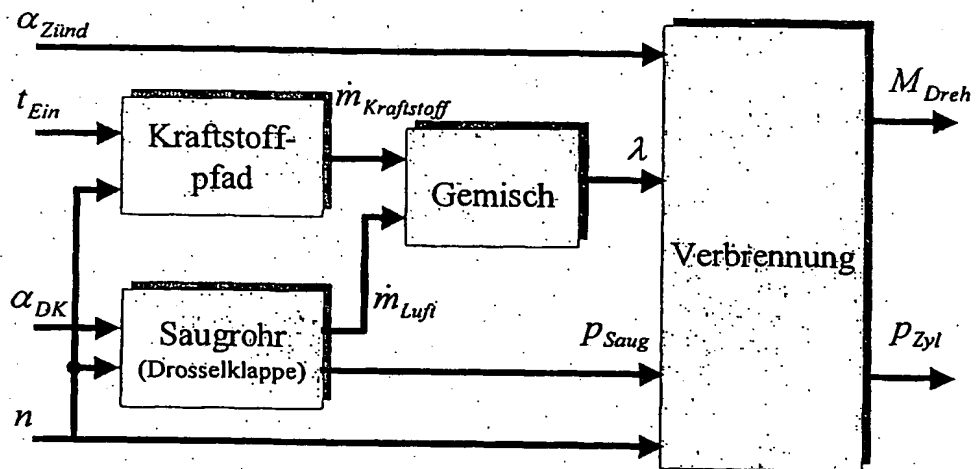


Abb. 5: Physikalisch motivierte Struktur eines Otto-Verbrennungsmotors

**This Page is Inserted by IFW Indexing and Scanning
Operations and is not part of the Official Record**

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:

- ☐ **BLACK BORDERS**
- ☐ **IMAGE CUT OFF AT TOP, BOTTOM OR SIDES**
- ☐ **FADED TEXT OR DRAWING**
- ☐ **BLURRED OR ILLEGIBLE TEXT OR DRAWING**
- ☐ **SKEWED/SLANTED IMAGES**
- ☐ **COLOR OR BLACK AND WHITE PHOTOGRAPHS**
- ☐ **GRAY SCALE DOCUMENTS**
- ☐ **LINES OR MARKS ON ORIGINAL DOCUMENT**
- ☐ **REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY**
- ☐ **OTHER:** _____

IMAGES ARE BEST AVAILABLE COPY.

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.